



**Prioritätsbescheinigung über die Einreichung
einer Patentanmeldung**

Aktenzeichen:

100 14 337.7

**CERTIFIED COPY OF
PRIORITY DOCUMENT**

Anmeldetag:

24. März 2000

Anmelder/Inhaber:

Philips Corporate Intellectual Property GmbH,
Hamburg/DE

Bezeichnung:

Verfahren zum Erzeugen eines Sprachmodells
und eines akustischen Modells für ein Sprach-
erkennungssystem

IPC:

G 10 L 15/00

**Die angehefteten Stücke sind eine richtige und genaue Wiedergabe der ur-
sprünglichen Unterlagen dieser Patentanmeldung.**

München, den 18. Oktober 2000
Deutsches Patent- und Markenamt
Der Präsident
Im Auftrag

Hoif

24.03.00



PHDE000046

ZUSAMMENFASSUNG

Erzeugung eines Sprachmodells und eines akustischen Modells für ein Spracherkennungssystem

- Die Erfindung betrifft ein Verfahren zur Erzeugung eines Sprachmodells und ein Verfahren zur Erzeugung eines akustischen Modells für ein Spracherkennungssystem. Es wird vorgeschlagen, das jeweilige Trainingsmaterial sukzessive um einzelne Trainingsmaterialan-
- 5 reile in Abhängigkeit von anwendungsspezifischen Daten zu reduzieren oder zu erweitern, um das jeweilige Trainingsmaterial zur Erzeugung des Sprachmodells und des akustischen Modells zu erhalten.

10

24.03.00

PHDE000046

BESCHREIBUNG

Verfahren zum Erzeugen eines Sprachmodells und eines akustischen Modells für ein Spracherkennungssystem

- 5 Die Erfindung betrifft ein Verfahren zur Erzeugung eines Sprachmodells für ein Spracherkennungssystem. Die Erfindung betrifft auch ein Verfahren zur Erzeugung eines akustischen Modells für ein Spracherkennungssystem.

- 10 Für die Erzeugung von Sprachmodellen und akustischen Modellen für Spracherkennungssysteme liegt umfangreiches Trainingsmaterial vor, das allerdings nicht anwendungsspezifisch ist. Das Trainingsmaterial für die Sprachmodellerzeugung beinhaltet üblicherweise eine Sammlung einer Vielzahl von Textdokumenten, z. B. Zeitungsartikeln. Das Trainingsmaterial für die Erzeugung eines akustischen Modells beinhaltet akustische Referenzen für Sprachsignalabschnitte.

- 15 Aus der WO 99/18556 ist es bekannt, aus einer verfügbaren Menge an Textdokumenten bestimmte Dokumente mit Hilfe eines Selektionskriterium zu selektieren und den durch die selektierten Dokumenten gebildeten Textkorpus der Sprachmodellbildung zugrunde zu legen. Es wird vorgeschlagen, die Dokumente im Internet zu suchen und die Selektion in Abhängigkeit von der Häufigkeit vorgegebener Schlüsselworte in den Dokumenten durch-
- 20 zuführen.

Der Erfindung liegt die Aufgabe zugrunde, die Sprachmodellerzeugung im Hinblick auf möglichst gute Ausnutzung von vorhandenem Trainingsmaterial zu optimieren.

- 25 Die Aufgabe wird dadurch gelöst, dass ein erster Textkorpus sukzessive um ein oder mehrere Textkorpusteile in Abhängigkeit von Textdaten eines anwendungsspezifischen zweiten Textkorpus reduziert wird und dass unter Verwendung des reduzierten ersten Textkorpus die Werte des Sprachmodells erzeugt werden.

30

Prezedenz 121899

24.03.00

PHDE000046

- Dieser Ansatz führt zu einem anwendungsspezifischen Sprachmodell mit reduzierter Perplexität und verringerter OOV-Rate, was schließlich die Wortfehlerrate des Spracherkennungssystems verbessert, wobei der Rechenaufwand möglichst klein gehalten wird. Außerdem kann man so ein Sprachmodell kleinerer Größe erzeugen, bei dem gegenüber einem
- 5 auf dem noch nicht reduzierten ersten Textkorpus basierenden Sprachmodell Sprachmodellbaumpfade eingespart werden können, so dass der Speicherplatzbedarf reduziert ist.

Vorteilhafte Ausgestaltungen sind in den Unteransprüchen 2 bis 6 angegeben.

- 10 Ein anderer Ansatz zur Sprachmodellerzeugung (Anspruch 7) beinhaltet, dass ein Textkorpusteil eines gegebenen ersten Textkorpusses in Abhängigkeit von Textdaten eines anwendungsspezifischen Textkorpusses sukzessive um ein oder mehrere andere Textkorpusteile des ersten Textkorpusses zur Bildung eines zweiten Textkorpusses erweitert wird und dass die Werte des Sprachmodells unter Verwendung des zweiten Textkorpusses
- 15 erzeugt werden. Im Gegensatz zum vorher beschriebenen Verfahren wird ein großer (Hintergrund-) Textkorpus nicht reduziert, sondern es werden sukzessive Anteile dieses Textkorpusses aufakkumuliert. Dies führt auf ein Sprachmodell mit ähnlich guten Eigenschaften wie ein nach dem vorher genannten Verfahren erzeugtes Sprachmodell.
- 20 Der Erfindung liegt auch die Aufgabe zugrunde, die Erzeugung des akustischen Modells des Spracherkennungssystems im Hinblick auf möglichst gute Ausnutzung von vorhandenem akustischem Trainingsmaterial zu optimieren.

- Diese Aufgabe wird dadurch gelöst, dass eine erste Anzahl von Sprachäußerungen repräsentierendes akustisches Trainingsmaterial sukzessive um einzelne Sprachäußerungen repräsentierende Trainingsmaterialanteile in Abhängigkeit von einer zweiten Anzahl anwendungsspezifischer Sprachäußerungen reduziert wird und dass mittels des reduzierten akustischen Trainingsmaterials die akustischen Referenzen des akustischen Modells
- 25 gebildet werden.

- 30 Dieser Ansatz führt auf ein kleineres akustisches Modell mit einer reduzierten Anzahl an akustischen Referenzen. Außerdem enthält das so erzeugte akustische Modell weniger im

24.03.00

PHDE000046

Merkmalsraum verstreute vereinzelte akustische Referenzen, die sich demgemäss nur schwer Anhäufungen (Clustern) von akustischen Referenzen zuordnen lassen. Das erfindungsgemäss erzeugte akustische Modell führt schließlich zu einer kleineren Wortfehlerrate des Spracherkennungssystems.

5

Entsprechende Vorteile gelten für den Ansatz, dass ein eine Sprachäußerung repräsentierender Anteil eines gegebenen akustischen Trainingsmaterials, das eine Vielzahl von Sprachäußerungen repräsentiert, sukzessive um ein oder mehrere andere Anteile des gegebenen akustischen Trainingsmaterials erweitert wird und das mittels der aufakkumulierten

10 Anteile des gegebenen akustischen Trainingsmaterials die akustischen Referenzen des akustischen Modells gebildet werden.

Ausführungsbeispiele der Erfindung werden nachfolgend anhand der Zeichnungen näher beschrieben. Es zeigen:

15

Fig. 1 ein Blockschaltbild eines Spracherkennungssystems und
Fig. 2 ein Blockschaltbild zur Erzeugung eines Sprachmodells für das
Spracherkennungssystem.

- 20 Fig. 1 zeigt die Grundstruktur eines Spracherkennungssystems 1, insbesondere eines Diktiersystems (z. B. FreeSpeech von Philips). Ein eingegebenes Sprachsignal 2 wird einer Funktionseinheit 3 zugeführt, die für dieses Signal eine Merkmalsextraktion (FE, "feature extraction") durchführt und dabei Merkmalsvektoren 4 erzeugt, die einer Verarbeitungseinheit 5 (MS, "matching unit") zugeführt werden. In der Verarbeitungseinheit 5, die das
- 25 Erkennungsergebnis ermittelt und ausgibt, wird in der bekannten Weise eine Pfadsuche durchgeführt, wobei ein akustisches Modell 6 (AM) und ein Sprachmodell 7 (LM) eingesetzt wird. Das akustische Modell 6 umfasst einerseits Modelle für Wortunterheiten wie beispielsweise Triphone, denen Folgen von akustischen Referenzen zugeordnet sind (Block 8) und ein Lexikon 9, das das verwendete Vokabular repräsentiert und mögliche Folgen
- 30 von Wortuntereinheiten vorgibt. Die akustischen Referenzen korrespondieren zu Zuständen von Hidden Markov Modellen. Das Sprachmodell 7 gibt N-Gramm-Wahrscheinlichkeiten an. Insbesondere wird ein Bigramm- oder ein Trigramm-Sprachmodell verwendet.

24.03.00

PHDE000046

Zur Erzeugung von Werten für die akustischen Referenzen und für die Erzeugung des Sprachmodells sind Trainingsphasen vorgesehen. Nähere Erläuterungen zum Aufbau des Spracherkennungssystems 1 lassen sich beispielsweise der WO 99/18556 entnehmen, deren Inhalt hiermit in diese Patentanmeldung einbezogen wird.

5 Mittlerweile existiert umfangreiches Trainingsmaterial sowohl für die Bildung eines Sprachmodells als auch für die Bildung eines akustischen Modells. Die Erfindung bezieht sich darauf, aus dem vorhandenen Trainingsmaterial die Anteile zu selektieren, die in Bezug auf die Anwendung möglichst optimal sind.

10

Die Selektion von Sprachmodell-Trainingsdaten aus vorhandenem Trainingsmaterial für die Erzeugung eines Sprachmodells zeigt Fig. 2. Ein erster Textkorpus 10 (Hintergrundkorpus C_{back}) stellt das zur Verfügung stehende Trainingsmaterial dar. Er besteht üblicherweise aus einer Vielzahl von Dokumenten, beispielsweise einer Vielzahl von Zeitungs-

15 artikeln. Unter Verwendung eines anwendungsspezifischen zweiten Textkorpus 11 (C_{target}), der Textbeispiele aus dem Anwendungsgebiet des Spracherkennungssystems 1 enthält, werden nun sukzessive Teile (Dokumente) aus dem ersten Textkorpus 10 entfernt, um einen reduzierten ersten Textkorpus 12 (C_{red}) zu generieren; auf der Basis des Textkorpus 12 wird das Sprachmodell 7 (LM, "Language Model") des Spracherkennungssystems 1
20 erzeugt, das besser auf das Anwendungsgebiet, aus dem der zweite Textkorpus 11 stammt, angepasst ist als ein Sprachmodell, dass auf der Basis des Hintergrundkorpus 10 erzeugt wurde. Übliche Prozeduren zur Erzeugung des Sprachmodells 7 aus dem reduzierten Textkorpus 11 sind durch den Block 14 zusammengefasst. Es werden Auftretshäufigkeiten der entsprechenden N-Gramme ausgewertet und in Wahrscheinlichkeitswerte umgesetzt. Dies
25 Prozeduren sind bekannt und werden deshalb nicht mehr näher erläutert. Ein Testkorpus 15 wird zur Bestimmung des Endes der Iteration zur Reduktion des ersten Trainingskorpus 10 verwendet.

Die Reduzierung des Textkorpus 10 wird auf folgende Art und Weise durchgeführt:

30

Ausgehend davon, dass der Textkorpus 10 aus Textkorpusteile darstellenden Dokumenten A_i ($i = 1, \dots, J$) zusammengesetzt ist, wird im ersten Iterationsschritt das Dokument A_i gesucht, das das M-Gramm-Selektionskriterium

24.03.00

PHDE000046

$$\Delta F_{i,M} = \sum_{x_M} N_{\text{spec}}(x_M) \log \frac{p(x_M)}{p_{A_i}(x_M)}$$

- maximiert. $N_{\text{spec}}(x_M)$ ist die Häufigkeit des M-Gramms x_M im anwendungsspezifischen Textkorporus 11, $p(x_M)$ ist die aus der Häufigkeit des M-Gramms x_M im Textkorporus 10
- 5 ermittelte M-Gramm-Wahrscheinlichkeit und $p_{A_i}(x_M)$ ist die aus der Häufigkeit des M-Gramms x_M im um den Textkorpusteil A_i reduzierten Textkorporus 10 ermittelte M-Gramm-Wahrscheinlichkeit.

- Der Zusammenhang zwischen einer ermittelten M-Gramm-Häufigkeit $N(x_M)$ und einem
- 10 zugehörigen Wahrscheinlichkeitswert $p(x_M)$ ergibt sich beispielsweise für sogenannte "backing-off"-Sprachmodelle aus der Formel

$$p(w|h) = \frac{N(w|h) - d}{N(h)} - \beta(w|h),$$

- 15 wobei ein M-Gramm x_M sich aus einem Wort w und einer zugehörigen Vergangenheit h zusammensetzt. d ist eine Konstante, $\beta(w|h)$ ist ein vom jeweiligen M-Gramm abhängiger Korrekturwert.

- Nachdem ein Dokument A_i auf diese Weise ermittelt wurde, wird der Textkorporus 10 um
- 20 dieses Dokument reduziert. Ausgehend von dem so erzeugten reduzierten Textkorporus 10 werden nun in nachfolgenden Iterationsschritten in entsprechender Weise Dokumente A_i mit Hilfe des genannten Selektionskriteriums $\Delta F_{i,M}$ aus dem bereits reduzierten Textkorporus 10 selektiert und der Textkorporus 10 sukzessive um weitere Dokumente A_i reduziert. Die Reduktion des Textkorporus 10 wird solange fortgesetzt, bis ein vorgebbares Kriterium
- 25 für den reduzierten Textkorporus 10 erfüllt ist. Ein solches Kriterium ist beispielsweise die Perplexität oder die OOV-Rate ("Out-Of-Vocabulary-Rate") des aus dem reduzierten Textkorporus 10 resultierenden Sprachmodells, die vorzugsweise mit Hilfe des kleinen Textkorporus 15 bestimmt werden. Die Perplexität und auch die OOV-Rate erreichen bei der sukzessiven Reduktion des Textkorpusses 10 ein Minimum und nehmen beim wei-

24.03.00

PHDE000046

teren Fortführen der Reduktion wieder zu. Vorzugsweise wird die Reduktion dann beendet, wenn dieses Minimum erreicht ist. Der schließlich durch Reduktion des Textkorpusses 10 am Ende der Iteration erhaltene Textkorpuss 12 wird als Basis zur Erzeugung des Sprachmodells 7 verwendet.

5

Einem Sprachmodell entspricht üblicherweise eine Baumstruktur, deren Baumkanten Wörter und deren Baumknoten Worthäufigkeiten zugeordnet sind. Im vorliegenden Fall wird eine solche Baumstruktur für den noch nicht reduzierten Textkorpuss 10 generiert. Wird nun der Textkorpuss 10 um bestimmte Anteile reduziert, werden bezüglich der betroffenen M-Gramme angepasste Häufigkeitswerte bestimmt; eine Anpassung der eigentlichen Baumstruktur, d.h. der Baumzweige und Baumverzweigungen, ist jedoch nicht erforderlich und erfolgt nicht. Nach jeder Auswertung des Selektionskriteriums $\Delta F_{i,M}$ werden die zugehörigen angepassten Häufigkeitswerte wieder gelöscht.

10

- 15 Alternativ zum sukzessiven Reduzieren einen gegebenen Hintergrundkorpusses kann ein zur Sprachmodellbildung verwendeter Textkorpuss auch dadurch gebildet werden, dass ausgehend von einem einzelnen Anteil (= Textdokument) des Hintergrundkorpusses sukzessive dieses Dokument um jeweils ein anderes Dokument des Hintergrundkorpusses zu einem akkumulierten Textkorpuss in Abhängigkeit von einem anwendungsspezifischen
- 20 Textkorpuss erweitert wird. Die zur Textkorpuserweiterung dienenden Anteile des Hintergrundkorpusses werden in den einzelnen Iterationsschritten mit Hilfe des folgenden Selektionskriteriums ermittelt.

$$\Delta F_{i,M} = \sum_{x_M} N_{\text{proc}}(x_M) \log \frac{p_{A_{\text{alt}}}(x_M)}{p_{A_{\text{alt}} + A_i}(x_M)}.$$

25

$p_{A_{\text{alt}}}(x_M)$ ist der der Häufigkeit des M-Gramms x_M in einem akkumulierten Textkorpuss A_{alt} entsprechende Wahrscheinlichkeit, wobei der akkumulierte Textkorpuss A_{alt} die Kombination von in vorausgehenden Iterationsschritten selektierten Dokumenten des Hintergrundkorpusses ist. Im aktuellen Iterationsschritt wird dasjenige noch nicht im

30 akkumulierten Textkorpuss enthaltene Dokument A_i des Hintergrundkorpusses selektiert, für

24.03.00

PHDE000046

das $\Delta F_{i,M}$ maximal ist; dieses wird mit dem verwendeten akkumulierten Textkorpus A_{akk} zu einem erweiterten Textkorpus kombiniert, der im nächsten Iterationsschritt als akkumulierter Textkorpus zugrundegelegt wird. Der Index $A_{akk}+A_i$ verweist auf die Kombination eines Dokuments A_i mit dem akkumulierten Textkorpus A_{akk} des aktuellen Iterationsschritts. Die Iteration wird abgebrochen, wenn ein vorgegbares Abbruchkriterium (siehe oben) erfüllt wird, z. B. wenn die im aktuellen Iterationsschritt gebildete Kombination $A_{akk}+A_i$ zu einem Sprachmodell mit minimaler Perplexität führt.

Bei der Erzeugung des akustischen Modells 6 werden entsprechende Ansätze verfolgt, d.h. aus einer gegebenen Menge an in Form von Merkmalsvektoren vorliegenden sprachlichen Äußerungen (akustisches Trainingsmaterial) werden in einer Ausführungsvariante diejenigen sukzessive selektiert, die zu einem optimierten anwendungsspezifischen akustischen Modell mit den zugehörigen entsprechenden akustischen Referenzen führen. Jedoch ist auch der umgekehrte Weg möglich, nämlich dass Teile des gegebenen akustischen Trainingsmaterials sukzessive zur Bildung des schließlich zur Bildung der für das Spracherkennungssystem verwendeten akustischen Referenzen aufakkumuliert werden.

Die Selektion von akustischem Trainingsmaterial wird wie folgt vorgenommen:

z_j bezeichne die Gesamtheit der im akustischen Trainingsmaterial enthaltenen Merkmalsvektoren, die durch Merkmalsextraktion entsprechend der von Block 3 aus Fig. 1 durchgeführten Prozeduren gebildet werden und zu Klassen (entsprechen beispielsweise Phonemen oder Phonemsegmenten oder Triphonen oder Triphonsegmenten) zusammengefasst sind. C_j sei ein Satz Beobachtungen einer Klasse j im Trainingsmaterial. C_j korrespondiert insbesondere zu einem bestimmten Zustand eines Hidden Markov Modells oder dazu entsprechend zu einem Phonem oder Phonemsegment. W_k bezeichne den Satz aller Beobachtungen von Merkmalsvektoren in der jeweiligen Trainingssprachäußerung k , die aus einem einzelnen Wort oder einer Wortfolge bestehen kann. N_k^j bezeichne die Anzahl Beobachtungen der Klasse j in einer Trainingssprachäußerung k . Weiterhin bezeichne y_i die Beobachtungen von Merkmalsvektoren eines Satzes vorgegebener anwendungsspezifischer Sprachäußerungen. Die folgenden Formeln setzen Gaußverteilungen mit entsprechenden Mittelwerten und Kovarianzwerten voraus.

24.03.00

PHDE000046

Es wird für eine Klasse C_j ein Mittelwertvektor

$$\mu_j = \frac{1}{N_j} \sum_{i \in C_j} x_i$$

- 5 definiert. Das Entfernen der Sprachäußerung k aus dem Trainingsmaterial bewirkt damit eine Mittelwertänderung bezüglich der Klasse C_j zu

$$\mu_j^k = \frac{1}{N_j - N_k^j} \left[N_j \mu_j - \sum_{i \in \{C_j\} \setminus \{w_k\}} x_i \right]$$

- 10 Damit ergibt sich durch die Reduktion des akustischen Trainingsmaterials um die Sprachäußerung k nunmehr ein Änderungswert von

$$\Delta F_k^j = \sum_j \sum_{i \in C_j^k} \left[-\frac{1}{2} (y_i - \mu_j^k)^T \frac{1}{\Sigma} (y_i - \mu_j^k) + \frac{1}{2} (y_i - \mu_j)^T \frac{1}{\Sigma} (y_i - \mu_j) \right],$$


- 15 wenn unveränderte Kovarianzwerte angenommen werden. Der Wert Σ wird wie folgt berechnet:

$$\Sigma = \frac{1}{N} \sum_i (x_i - \mu)^T (x_i - \mu)$$

- 20 mit N als Anzahl aller Merkmalsvektoren im nicht reduzierten akustischen Trainingsmaterial und μ als Mittelwert für alle diese Merkmalsvektoren.

Dieser Änderungswert kommt grundsätzlich schon als Kriterium für die Selektion von Sprachäußerungen, um die das akustische Trainingsmaterial reduziert wird, in Frage. Soll

- 25 auch die Änderung von Kovarianzwerten mit in Betracht gezogen werden. Diese sind definiert durch



$$\Sigma_j = \frac{1}{N_j} \sum_{i \in C_j} (x_i - \mu_j)^T (x_i - \mu_j).$$

Nach Entfernen der Sprachäußerung k aus dem Trainingsmaterial ergibt sich eine Kovarianz von

5

$$\Sigma_j^k = \frac{1}{N_j - N_k^j} \left[N_j \Sigma_j - \sum_{i \in \{C_j\}, i \in \{w_k\}} (x_i - \mu_j)^T (x_i - \mu_j) \right],$$

so dass sich schließlich ein Änderungswert (logarithmischer Wahrscheinlichkeitswert) von

$$10 \quad \Delta F_k = \sum_j \sum_{i \in T_j^k} \left[-\frac{1}{2} \log \det(\Sigma_j^k) - \frac{1}{2} (y_i - \mu_j^k)^T \frac{1}{\Sigma_j^k} (y_i - \mu_j^k) + \frac{1}{2} \log \det(\Sigma_j) + \frac{1}{2} (y_i - \mu_j)^T \frac{1}{\Sigma_j} (y_i - \mu_j) \right]$$

ergibt, der dann als Selektionskriterium verwendet wird. Sukzessive wird das akustische Trainingsmaterial um jeweils einen der selektierten Sprachäußerung k entsprechenden

- 15 Anteil reduziert, was sich in einem entsprechend geänderten Mittelwert μ_j^k und einer entsprechend geänderten Kovarianz Σ_j^k für die jeweilige Klasse j gemäß den oben angeführten Formeln niederschlägt. Die beim Ende der Iteration erhaltenen Mittelwerte und Kovarianzen bezüglich der verschiedenen noch im Trainingsmaterial verbliebenen Sprachäußerungen werden zur Bildung der akustischen Referenzen (Block 8) des Spracherkennungssystems 1 verwendet. Die Iteration wird abgebrochen, wenn ein vorgebbares Abbruchkriterium erfüllt ist. Beispielsweise wird in jedem Iterationsschritt für das sich ergebende akustische Modell und eine Test-Spracheingabe (Wortfolge) die sich ergebende Wortfehlerrate des Spracherkennungssystems ermittelt. Ist die sich ergebende Wortfehlerrate ausreichend gering oder wird ein Minimum der Wortfehlerrate erreicht, wird die
- 20
- 25 Iteration abgebrochen.

Ein anderer Ansatz zur Bildung des akustischen Modells eines Spracherkennungssystems geht davon aus, dass ein eine Sprachäußerung repräsentierender Anteil eines gegebenen

24.03.00

PHDE000046

- akustischen Trainingsmaterials, das eine Vielzahl von Sprachäußerungen repräsentiert, sukzessive um ein oder mehrere andere Anteile des gegebenen akustischen Trainingsmaterials erweitert wird und das mittels der aufakkumulierten Anteile des gegebenen akustischen Trainingsmaterials die akustischen Referenzen des akustischen Modells
- 5 gebildet werden. Bei diesem Ansatz wird in jedem Iterationsschritt eine Sprachäußerung k ermittelt, die ein Selektionskriterium $\Delta F'_k$ oder ΔF_k gemäß den oben angeführten Formeln maximiert. Anstatt gegebenes akustisches Trainingsmaterial sukzessive zu reduzieren, werden jeweils einer einzelnen Sprachäußerung entsprechende Teile des gegebenen akustischen Trainingsmaterials aufakkumuliert, und zwar in jedem Iterationsschritt jeweils
- 10 um den einer einzelnen Sprachäußerung k entsprechenden Anteil des gegebenen akustischen Trainingsmaterials. Die Formeln für μ_j^k und Σ_j^k müssen dabei wie folgt modifiziert werden:

$$\mu_j^k = \frac{1}{N_j + N_k^j} \left[N_j \mu_j + \sum_{i \in \{c_j\}, i \in \{w_k\}} x_i \right];$$

15

$$\Sigma_j^k = \frac{1}{N_j + N_k^j} \left[N_j \Sigma_j + \sum_{i \in \{c_j\}, i \in \{w_k\}} (x_i - \mu_j)^T (x_i - \mu_j) \right].$$

Die übrigen Formeln können unverändert verwendet werden.

- 20 Die beschriebenen Ansätze zur Bildung des akustischen Modells eines Spracherkennungssystems sind grundsätzlich für alle Verklebungsarten für Mittelwerte und Kovarianzen und alle Arten der Modellierung von Kovarianzen (z. B. Skalar, Diagonalmatrix, Vollmatrix) geeignet. Die Ansätze sind auch nicht auf Gaußverteilungen beschränkt, sondern lassen sich auch beispielsweise auf Laplaceverteilungen umschreiben.

25

24.03.00
- 11 -

PHDE000046

PATENTANSPRÜCHE

1. Verfahren zur Erzeugung eines Sprachmodells (7) für ein Spracherkennungssystem (1),
dadurch gekennzeichnet,

dass ein erster Textkorporus (10) sukzessive um ein oder mehrere Textkorpusteile in
Abhängigkeit von Textdaten eines anwendungsspezifischen zweiten Textkorporus (11)

5 reduziert wird und

dass unter Verwendung des reduzierten ersten Textkorporus (12) die Werte des
Sprachmodells (7) erzeugt werden.

2. Verfahren nach Anspruch 1,

10 dadurch gekennzeichnet,

dass zur Bestimmung der Textkorpusteile, um die der erste Textkorporus (10) reduziert
wird, Unigrammhäufigkeiten im ersten Textkorporus (10), im reduzierten ersten Textkorporus
(12) und im zweiten Textkorporus (12) ausgewertet werden.

15 3. Verfahren nach Anspruch 2,

dadurch gekennzeichnet,

dass zur Bestimmung der Textkorpusteile, um die der erste Textkorporus (10) in einem
ersten Iterationsschritt und in entsprechender Weise in weiteren Iterationsschritten
reduziert wird, das folgende Selektionskriterium verwendet wird:

20

$$\Delta F_{i,M} = \sum_{x_M} N_{\text{pec}}(x_M) \log \frac{p(x_M)}{p_{A_i}(x_M)}$$

mit $N_{\text{pec}}(x_M)$ als Häufigkeit des M-Gramms x_M im zweiten Textkorporus, $p(x_M)$ als aus der
Häufigkeit des M-Gramms x_M im ersten Trainingskorporus ermittelte M-Gramm-Wahr-

24.03.00
-12-

PHDE000046

scheinlichkeit und $p_{A_i}(x_M)$ als aus der Häufigkeit des M-Gramms x_M im um den Textkorpusteil A_i reduzierten ersten Trainingskorporus ermittelte M-Grammwahrscheinlichkeit.

- 5 4. Verfahren nach Anspruch 3,
dadurch gekennzeichnet,
dass Trigramme mit $M = 3$ oder Bigramme mit $M = 2$ oder Unigramme mit $M = 1$ zugrunde gelegt werden.
- 10 5. Verfahren nach einem der Ansprüche 1 bis 4,
dadurch gekennzeichnet,
dass zur Ermittlung des Endes der Reduktion des ersten Trainingskorpusses (10) ein Testtext (15) ausgewertet wird.
- 15 6. Verfahren nach Anspruch 5,
dadurch gekennzeichnet,
dass die Reduktion des ersten Trainingskorpusses (10) beim Erreichen eines bestimmten Perplexitätswertes oder einer bestimmten OOV-Rate des Testtextes, insbesondere beim Erreichen eines Minimums, beendet wird.
- 20 7. Verfahren zur Erzeugung eines Sprachmodells (7) für ein Spracherkennungssystem (1),
dadurch gekennzeichnet,
dass ein Textkorpusteil eines gegebenen ersten Textkorpusses in Abhängigkeit von Textdaten eines anwendungsspezifischen Textkorpusses sukzessive um ein oder mehrere
25 andere Textkorpusteile des ersten Textkorpusses zur Bildung eines zweiten Textkorpusses erweitert wird und dass die Werte des Sprachmodells (7) unter Verwendung des zweiten Textkorpusses erzeugt werden.

24.03.00

-13-

PHDE000046

8. Verfahren zum Erzeugen eines akustischen Modells (6) für ein Spracherkennungssystem (1),

dadurch gekennzeichnet,

dass eine erste Anzahl von Sprachäußerungen repräsentierendes akustisches

- 5 Trainingsmaterial sukzessive um einzelne Sprachäußerungen repräsentierende Trainingsmaterialanteile in Abhängigkeit von einer zweiten Anzahl anwendungsspezifischer Sprachäußerungen reduziert wird und
- dass mittels des reduzierten akustischen Trainingsmaterials die akustischen Referenzen (8) des akustischen Modells (6) gebildet werden.

10

9. Verfahren zum Erzeugen eines akustischen Modells (6) für ein Spracherkennungssystem (1),

dadurch gekennzeichnet,

dass ein eine Sprachäußerung repräsentierender Anteil eines gegebenen akustischen

- 15 Trainingsmaterials, das eine Vielzahl von Sprachäußerungen repräsentiert, sukzessive um ein oder mehrere andere Anteile des gegebenen akustischen Trainingsmaterials erweitert wird und das mittels der aufakkumulierten Anteile des gegebenen akustischen Trainingsmaterials die akustischen Referenzen (8) des akustischen Modells (6) gebildet werden.

20

10. Spracherkennungssystem mit einem nach einem der Ansprüche 1 bis 7 erzeugten Sprachmodell und/oder einem nach Anspruch 8 oder 9 erzeugten akustischen Modell.

24.03.00

AF

1/1




FIG. 1




FIG. 2

PHDE000046